

**SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU**  
**ELEKTROTEHNIČKI FAKULTET**

**Sveučilišni diplomski studij računarstva**

**SEMANTIČKA SEGMENTACIJA RGB-D SLIKE**  
**UNUTRAŠNJIH PROSTORA**

**Diplomski rad**

**Kristijan Šimić**

**Osijek, 2015.**

# SADRŽAJ

1. UVOD .....	1
2. SEMANTIČKA SEGMENTACIJA SLIKE PUTEM UVJETNIH SLUČAJNIH POLJA .....	2
2.1. Struktura uvjetnog slučajnog polja.....	3
2.1.1. Minimalno razapinjuće stablo grafa.....	4
2.2. Potencijali uvjetnog slučajnog polja .....	6
2.2. Kd-stabla .....	10
2.3. Algoritam K najbližih susjeda.....	12
2.3. Zaključivanje i dekodiranje .....	14
3. SEGMENTIRANJE SLIKE NA SUPERPIKSELE .....	18
3.1. RGB prostor boja .....	18
3.2. CIE L*a*b* prostor boja .....	19
3.2.1. Transformacija iz RGB u CIE L*a*b* prostor boja .....	19
3.3. SLIC Algoritam .....	20
3.3.1. Postprocesiranje grupa piksela.....	23
3.3.2. Programska implementacija SLIC algoritma.....	23
4. ZNAČAJKE SUPERPIKSELA.....	26
4.1. 3D značajke .....	27
4.1.1. Pronalaženje dominantne ravnine RANSAC metodom .....	28
4.1.2. Računanje 3D značajki .....	29
4.2. Značajke slike .....	31
5. EKSPERIMENTALNI REZULTATI .....	34
6. ZAKLJUČAK .....	42
LITERATURA .....	43
SAŽETAK.....	44
ABSTRACT .....	45

## SAŽETAK

U ovom radu je analiziran jedan pristup rješavanju problema semantičke segmentacije dubinskih slika unutrašnjih prostora. Proučeni su algoritmi korišteni u predloženoj metodi, kao i njihove programske implementacije. Rješavanjem problema semantičke segmentacije slike znatno bi se poboljšala sposobnost robota za samostalan rad u nepoznatim okruženjima. Problem se svodi na svrstavanje dijelova slike u neke unaprijed određene kategorije. U ovom slučaju te kategorije su pod, strukture, namještaj i rekviziti. Predložena metoda kategorizira dijelove slike koristeći uvjetna slučajna polja. Slika se najprije segmentira na superpiksela, koji služe kao čvorovi grafa uvjetnog slučajnog polja. Potencijali uvjetnog slučajnog polja određeni su vizualnim i geometrijskim značajkama superpiksela. Struktura grafa je minimalno razapinjuće stablo, pri čemu je težina brida određena na temelju udaljenosti centroida dvaju superpiksela u trodimenzionalnom prostoru. U okviru ovog rada proučena je jedna metoda zaključivanja i dekodiranja uvjetnih slučajnih polja koja omogućuje pronalaženje optimalne segmentacije. Učinkovitost predložene metode ispitana je eksperimentima na ispitnom skupu dubinskih slika unutrašnjih prostora.

**Ključne riječi:** računalni vid, semantička segmentacija, uvjetna slučajna polja, minimalno razapinjuće stablo, algoritam k najbližih susjeda, propagacija vjerojatnosti, RGB-D slika, SLIC superpikseli

## ABSTRACT

This thesis considers an approach for semantic segmentation of RGB-D images of indoor environments. The algorithms used in this approach are described and their implementation in the provided source code is explained. Solving the problem of semantic RGB-D image segmentation would significantly improve the capacity of robots for autonomous problem solving in unknown environments. The considered problem is to classify parts of an image into a set of predefined categories. In this case, the categories are ground, structure, furniture and props. The discussed method does this using the conditional random fields. The image is first segmented into superpixels, which serve as nodes in a CRF graph, where the CRF potentials are defined by visual and geometric features of the superpixels that the image is divided into. The structure of the CRF graph is a minimum spanning tree, with the weight of the graph edges being defined by the distance between the superpixel centroids in three-dimensional space. One method for CRF inference and decoding, which provides an optimal segmentation, is examined. The efficacy of the considered approach is tested on a set of RGB-D images of indoor environments.

**Key words:** computer vision, semantic segmentation, conditional random fields, minimum spanning trees, k-NN, belief propagation, RGB-D, SLIC superpixels